MODELOWANIE ZACHOWANIA KOMÓREK NERWOWYCH W KONTEKŚCIE PROSTYCH SIECI NEURONOWYCH

MODELLING OF NEURONS BY MEANS OF SIMPLE NEURAL NETWORKS

Tomasz Spustek*

Abstract
In the paper an overview of most popular artificial neuron models can be found. Analysis and of chosen models has been carried. Attention has been called on the use of discussed models in simple neural networks.

1. Wstęp

Sieci neuronowe to w istocie mniej lub bardziej skomplikowane modele rzeczywistego układu nerwowego. Zbudowane są z szeregu identycznych, wzajemnie połączonych obiektów, którym nadano umowną nazwę neuronów, ze względu na pewne podobieństwa do rzeczywistych komórek nerwowych. Ważną cechą sieci neuronowych jest możliwość ich uczenia (trenowania). Rozumie się przez to, modyfikowanie parametrów ich części składowych w taki sposób, by uzyskać jak najlepsze rezultaty podczas rozwiązywania danej klasy problemów.

Pierwowzorem sieci neuropodobnych jest ludzki mózg, a w zasadzie kora mózgowa. Szacuje się, że składa się ona z 10^{10} komórek nerwowych oraz 10^{12} komórek glejowych, tworzących łącznie ok. 10^{15} połączeń. Zadziwiająca jest szybkość pracy mózgu, która dorównuje możliwościom współczesnych komputerów. Ponadto ludzki umysł jest w stanie rozwiązywać problemy, których nie można rozwiązać za pomocą klasycznych algorytmów obliczeniowych. Przykładem może być rozpoznawanie kształtów lub dźwięków. Poprawnie zaprojektowana i dobrze „wytrenowana" sieć neuronowa działa w sposób bardzo zbliżony do ludzkiego układu nerwowego. Dzięki temu możliwe staje się rozwiązywanie przez maszynę problemów, które zwyczajowo uważa się za „ludzkie". Jednym z najczęściej przytacza-

* mgr Tomasz SPUSTEK, Instytut Fizyki Doświadczalnej Uniwersytetu Warszawskiego.

nych przykładów zastosowania sieci neuronowych jest algorytm, skutecznie rozpoznający zmiany nowotworowe na zdjęciach rentgenowskich.

2. Rzeczywista komórka nerwowa, a „sztuczny neuron”

Komórka nerwowa (neuron), przedstawiona w uproszczeniu na rys. 1, odpowiedzialna jest w organizmie za odbiór i wysyłanie impulsów elektrycznych. Najważniejszymi elementami składowymi neuronu są (Kandel, 2000, s. 23-35):

- jądro komórkowe - odpowiedzialne za wszystkie procesy zachodzące w komórce, w tym podejmowanie decyzji,
- dendryty - silnie rozgałęzione wypustki plazmatyczne pełniące funkcje wejścia dla impulsów elektrycznych,
- akson - za jego pomocą sygnał jest wysyłany do sąsiednich komórek nerwowych lub narządów wykonawczych (np. mięśni),
- synapsy - zakończenia dendrytów, przez nie sygnał zostaje przekazany do wnętrza komórki,
- wzgórek aksonalny - miejsce, z którego nadawany jest sygnał wyjściowy, propagujący się następnie poprzez akson do kolejnych komórek nerwowych.

Rys. 1: Przykładowa komórka nerwowa

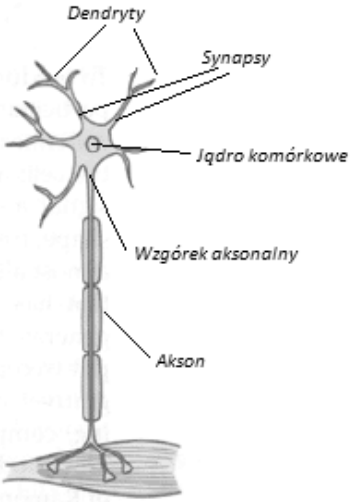

Źródło: Opracowano na podstawie (Kandel, 2000, s. 29).

W uproszczony sposób działanie komórki nerwowej można sprowadzić do zagadnienia przekazywania impulsów elektrycznych. Sygnał dociera do jądra komórki za pośrednictwem dendrytów oraz synaps. W zależności od konfiguracji pobudzenia neuronu we wzgórku aksonalnym może zostać wytworzony potencjał czynnościowy. Jeśli tak się stanie, powstanie nowy impuls elektryczny, który za pośrednictwem aksonu zostanie przekazany do kolejnych komórek nerwowych powodując ich pobudzenie.

Nietrudno zauważyć swoistą analogię do prostego przetwornika sygnałów, posiadającego szereg wejść i jedno wyjście (por. rys. 2). Przedstawione rozumowanie jest jedynie przybliżeniem skomplikowanych procesów zachodzących w rzeczywistej komórce nerwowej, jednak w oparciu o ten model można zbudować w pełni funkcjonalną sieć neuronową. Sztuczny neuron może zostać zaimplementowany na wiele różnych sposobów. Przykładowo wartość wyjściowa może zostać opisana następującą liniową zależnością funkcyjną (Tadeusiewicz, 1993, s. 27-29):

$$\vartheta(x_1, x_2, \ldots, x_n) = \sum_{i=1}^{n} x_i w_i$$

gdzie:
- kolejne sygnały wejściowe,
- wagi synaptyczne (mogą przyjmować dowolne wartości, także ujemne).

Rys. 2: Schematyczny rysunek pojedynczego neuronu

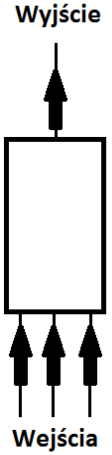

Źródło: Opracowanie własne.

W modelu tym sygnały wejściowe są skalowane przy pomocy pewnych wag. Oznacza to, że impulsy pochodzące od dendrytów do których przypisano wyższe współczynniki są bardziej istotne, niż te pochodzące od innych. Tym samym, wybrane sygnały wejściowe mają większy wpływ na to, czy komórka zostanie pobudzona i przekaże sygnał na wyjście, czy też nie. Może zdarzyć się także sytuacja, w której niektóre współczynniki są mniejsze od zera. Oznacza to, że kanały wejściowe, do których są przypisane mają za zadanie utrudniać pobudzanie neuronu. Posługując się modelem tak działającego neuronu można zmieniać zachowanie komórki poprzez modyfikowanie zestawu współczynników.

Zastosowania modelu liniowego pojedynczego neuronu w sieci są ograniczone. Sieci tego typu zazwyczaj działają wolno. Ponadto łączenie kolejnych grup takich jednostek obliczeniowych nie powoduje żadnej poprawy jakości otrzymywanych wyników, ze względu na prosty fakt, że złożenie funkcji liniowych jest nadal zależnością liniową.

W praktyce wykorzystuje się modele nieliniowe. Najprostszym z nich jest model McCulloch'a, opisany przez tzw. *funkcję skoku jednostkowego (*ang. *Theta Heaviside'a)*:

$$\vartheta(x_1, x_2, \ldots, x_n) = \begin{cases} 1 & dla \quad \sum_{i=1}^{n} x_i w_i < T \\ 0 & dla \quad \sum_{i=1}^{n} x_i w_i \geq T \end{cases}$$

gdzie:
- kolejne sygnały wejściowe,
- wagi synaptyczne (mogą przyjmować dowolne wartości, także ujemne),
- arbitralnie dobrana wielkość progowa.

Ten prosty w swej istocie model umożliwia już dobre zrealizowanie takich funkcji logicznych, jak NOT, OR, AND, a nawet NOR lub NAND (McCulloch, 1943, s. 4-12). Z drugiej strony możliwa jest obsługa jedynie wartości binarnych (tj. 0 i 1).

Możliwe jest jednak wprowadzenie pewnej modyfikacji, a w zasadzie uogólnienia przedstawionego modelu pojedynczej komórki nerwowej. Wystarczy jako funkcję aktywacji neuronu przyjąć tzw. *sigmoidę*, której szczególnym przypadkiem jest zastosowana poprzednio funkcja *theta*. Wówczas model będzie opisany przez następujące równanie:

$$\vartheta(x_1, x_2, \ldots, x_n) = \frac{1}{1 + e^{-\beta \sum_{i=1}^{n} x_i w_i}} \tag{3}$$

w którym:
- kolejne sygnały wejściowe,
- współczynnik aktywacji, dodatkowy parametr określający pobudliwość neuronu,
- wagi synaptyczne (mogą przyjmować dowolne wartości, także ujemne).

Pojedyncza komórka nerwowa modelowana zgodnie z przedstawionym powyżej schematem, tworzy najprostszą stosowaną obecnie sieć neuronową - jednoelementową. W praktyce stosuje się sieci neuronowe zbudowane z większej liczby elementów. Umożliwia to realizacje większej liczby zależności między funkcją wejściową a wyjściową układu, przez co możliwe staje się rozwiązanie coraz bardziej złożonych problemów. Z drugiej jednak strony rośnie liczba różnych wag opisujących sieć.

3. Łączenie neuronów w sieć

Możliwych do zrealizowania topologii sieci neuronowej jest bardzo dużo. Większość z nich powstała na potrzeby próby rozwiązania pewnej klasy problemów. Często spotykaną architekturą sieci neuronowej jest tzw. wielowarstwowa *sieć jednokierunkowa*, której przykładową strukturę przedstawia rys. 3. Jak można zauważyć, sieć ta składa się z neuronów modelowanych zgodnie z (3), ułożonych w warstwy. Komórki należące do danej warstwy nie komunikują się ze sobą, a aksony (wyjścia) neuronów w danej warstwie są połączone ze wszystkimi dendrytami (wejściami) komórek w warstwie następnej. Sygnał może być przekazywany tylko w jednym kierunku.

Rys. 3: Trójwarstwowy model jednokierunkowej sieci neuronowej

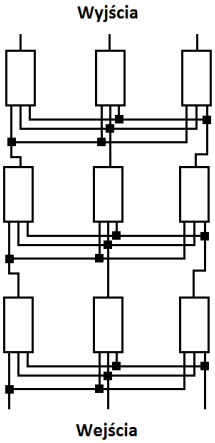

Źródło: Opracowanie własne.

Poprzez odpowiedni dobór kolejnych współczynników wagowych możliwe jest wpłynięcie na działanie całej sieci. Proces dobierania stosownych parametrów nazywany jest *uczeniem* sieci neuronowej, bądź jej *trenowaniem*. Mechanizm uczący ma za zadanie sprawić, czy po podaniu sygnału wejściowego, na wyjściu systemu, otrzymany zostanie interesujący rezultat. W celu przyuczenia sieci neuronowej do pracy nad konkretnym problemem potrzebna jest znajomość kilku zestawów danych, które charakteryzują problem w określonym zakresie.

Załóżmy, że dla rozważanego problemu znane są wyniki, dla pewnego zestawu danych wejściowych. Uczenie sieci neuronowej może polegać na podaniu na wejście układu, a następnie takie modyfikowanie wag, aby zminimalizować różnicę między otrzymanym wynikiem a znanym rezultatem. W trakcie uczenia przeprowadzana jest więc stopniowa modyfikacja parametrów sieci w taki sposób, aby dla znanych danych otrzymać poprawne wartości.

Charakterystyczny przebieg funkcji (por. wzór 3) sprawia, że na zbliżone konfiguracje sygnałów wejściowych sieć neuronowa będzie reagować w zbliżony sposób. Tym samym, sieci neuronowe charakteryzują się mechanizmem działania podobnym w swej istocie do myślenia kontekstowego. Mechanizm ten opiera się na możliwości analizy sygnału pod kątem najważniejszych jego cech, z pominięciem tych nieistotnych. Jest to bardzo

pożądana cecha charakterystyczna opisywanych układów i to właśnie dzięki niej sieci neuronowe nazywa się czasem *sztuczną inteligencją*.

4. Podsumowanie

Sztuczne sieci neuronowe są niezwykle elastycznym narzędziem często umożliwiającym znalezienie rozwiązania w sytuacji, gdy standardowe algorytmy obliczeniowe zawodzą. Znajdują zastosowanie w numerycznych metodach rozpoznawania wzorców oraz przy prognozowaniu. Większość współczesnych algorytmów prognozujących, używanych np. do przewidywania pogody, opiera swe działanie na sieciach neuronowych. Ponadto należy zdawać sobie sprawę z niedoskonałości takich rozwiązań. Przede wszystkim sieć neuronowa może dać odpowiedź błędną. Dzieje się tak bardzo często podczas wykonywania precyzyjnych obliczeń celem przeprowadzania wieloetapowej analizy skomplikowanych danych.

LITERATURA

Kandel E.R., Schwartz J.H., Jessell T., Principles of Neural Science. New York, 2000.

McCulloch W., Pitts W. A., logical calculus of the ideas immanent in nervous activity. “Bulletin of Mathematical Biophysics”, 1943.

Rosenblatt F., The Perceptron - a perceiving and recognizing automaton. Report 85 460-1, Cornell Aeronautical Laboratory, 1957.

Tadeusiewicz R., Sieci neuronowe. Warszawa: Akademicka Oficyna Wyd. RM, 1993.

Hoppensteadt F.C., Izhikevich E.M., Weakly connected neural networks. Springer, 1999.